

基于 ALOS 遥感数据纹理及纹理指数的柞树蓄积量估测*

刘俊¹ 毕华兴¹ 朱沛林² 孙菁³ 朱金兆¹ 陈涛⁴

(1. 北京林业大学水土保持学院, 北京 100083; 2. 北京林业大学林学院, 北京 100083;

3. 瑞典皇家工学院城市规划与环境系, 斯德哥尔摩 10044; 4. 国家海洋局海洋咨询中心, 北京 100860)

摘要: 以北京市怀柔区柞树林为研究对象, 通过计算 ALOS 卫星 2.5 m 分辨率融合影像在不同窗口下的纹理特征及衍生纹理指数, 采用多元逐步回归模型建立柞树地面实测蓄积量与 ALOS 影像纹理特征及衍生纹理指数的相关关系, 比较纹理特征及衍生纹理指数拟合柞树蓄积量模型的精度, 筛选最优反演模型及最优纹理生成窗口。结果表明: 同一纹理生成窗口下, 基于衍生纹理指数的柞树蓄积量反演模型 ($R_{\text{adj}}^2 = 0.603$, RMSE 为 $19.8994 \text{ m}^3/\text{hm}^2$) 精度优于基于纹理特征的柞树蓄积量反演模型 ($R_{\text{adj}}^2 = 0.217$, RMSE 为 $27.9438 \text{ m}^3/\text{hm}^2$); 结合同一窗口的纹理特征及衍生纹理指数进行柞树蓄积量建模, 精度可进一步提升 ($R_{\text{adj}}^2 = 0.747$, RMSE 为 $15.8876 \text{ m}^3/\text{hm}^2$); 基于所有窗口的纹理特征及衍生纹理指数建立多元逐步回归模型, 可得到柞树蓄积量估测的最优模型 ($R_{\text{adj}}^2 = 0.807$, RMSE 为 $13.8565 \text{ m}^3/\text{hm}^2$); 11×11 窗口为最优纹理生成窗口, 其对应最优单窗口模型拟合优度为: $R_{\text{adj}}^2 = 0.747$, RMSE 为 $15.8876 \text{ m}^3/\text{hm}^2$ 。

关键词: 柞树 蓄积量 遥感 纹理特征 衍生纹理指数

中图分类号: S758.5⁺1; TP79 **文献标识码:** A **文章编号:** 1000-1298(2014)07-0245-10

引言

森林蓄积量是指森林中全部树木材积的总和^[1], 是森林地上生物量部分的重要组成, 也是森林固碳能力的重要标志^[2]。由于调查周期长、劳动强度大、耗费大量人财物力等缺点, 传统的一、二类森林资源调查法获取森林蓄积量数据不能及时准确地反映大面积森林蓄积量的分布状况及动态变化^[3-5]。近 30 年来, 兼具宏观、动态、实时等特点的遥感技术, 逐渐成为资源监测的重要手段^[6]。利用高空间分辨率遥感数据光谱信息与森林参数间较强的相关性, 对 LAI、胸径、生物量等森林特征因子进行估测, 国内外已开展了许多相关研究工作^[2,7-13]。按照机理的不同, 这些研究大致可分为两类: 一类是利用遥感数据的光谱信息、衍生植被指数与地面实测数据建立回归模型^[6-9]; 另一类则是利用神经网络模型对目标参数进行估测^[2,10]。基于遥感数据光谱信息在不同尺度上估测森林参数的模型已有很多, 但由于立木冠层阴影、植被立地结构的异质性和光谱数据饱和性的影响, 仅依靠遥感光谱信息进行森林参数反演, 普遍存在精度不高的问题^[14-16]; 基

于神经网络的森林参数反演则因无法从逻辑上给出明确的数学模型, 限制了其在大尺度上的拓展应用^[10]。较之光谱信息及植被指数, 遥感数据的纹理特征^[17]扩大了基于原始影像亮度的空间信息辨识度, 基于纹理特征的地表参数反演精度具有很大的提升潜力^[18-19]。利用高分辨率遥感影像纹理特征进行森林参数的反演, 国外已取得较大进展^[11-13,18-19], 国内则多侧重于利用纹理特征进行影像的分类研究^[20-24], 利用纹理特征进行森林蓄积量、生物量的反演却关注较少。本文借鉴国外遥感反演森林参数的经验, 利用 ALOS 卫星 2.5 m 分辨率融合数据生成多种纹理特征及基于纹理特征的衍生纹理指数, 结合北京市怀柔区柞树地面实测样地蓄积量数据建立多元逐步回归模型, 旨在探讨高分辨率影像纹理信息在森林蓄积量估测中的应用。

1 研究区与实验数据

1.1 研究区概况

研究区位于北京市怀柔区(图 1), 该区地处北京市北部, 属北京市远郊区, 地理坐标为 $40^{\circ}14' \sim 40^{\circ}04' \text{N}$ 、 $116^{\circ}17' \sim 116^{\circ}53' \text{E}$ 。怀柔区位于燕山南

收稿日期: 2014-03-07 修回日期: 2014-04-03

* 北京市教育委员会省部共建项目(2009GJKY01)

作者简介: 刘俊, 博士生, 主要从事森林遥感研究, E-mail: liujun_china@bjfu.edu.cn

通讯作者: 毕华兴, 教授, 博士生导师, 主要从事水土保持、林业生态工程研究, E-mail: bxh@bjfu.edu.cn

麓,总面积 2 128.7 km²,境内地势北高南低,海拔高度在 34~1 661 m 之间,分为深山区、浅山区、丘陵和平原 4 种地形,其中山区面积 88.7%,宜林山场林木覆盖率为 41%。据 2006 年北京市森林资源二类清查数据显示,怀柔区有柞树、油松、侧柏、刺槐、杨树等多个乔木树种分布;其中,柞树分布面积约为 43 918.3 hm²,占全区各类林地面积总和的 24.0%,占全区乔木林地总面积的 51.3%,是怀柔区最主要的乔木树种。

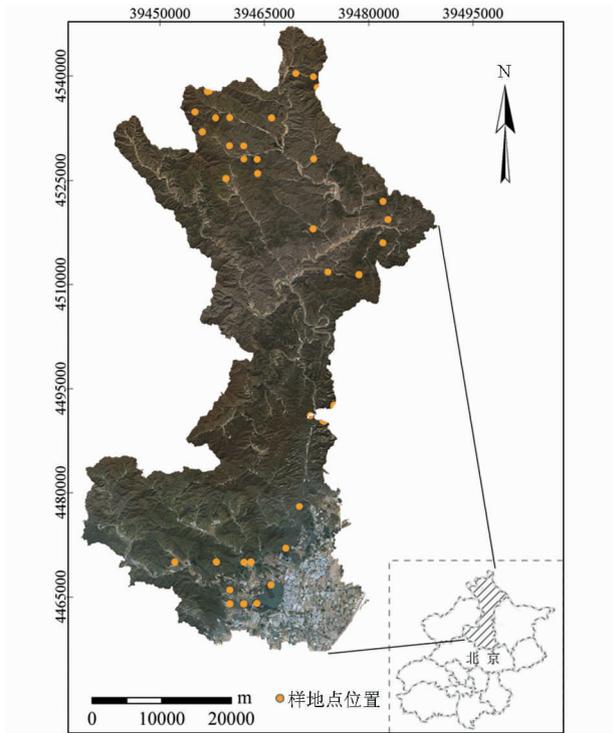


图 1 研究区及样地点位置图

Fig. 1 Study area and location of sample plots

1.2 遥感数据源

本研究使用的遥感数据为 ALOS (Advanced land observation satellite) 遥感影像。全色数据刈幅 35 km × 70 km,分辨率 2.5 m;多光谱数据刈幅 70 km × 70 km,分辨率 10 m;多光谱数据波段组成分别为蓝光波段 (0.42 ~ 0.50 μm)、绿光波段 (0.52 ~ 0.60 μm)、红光波段 (0.61 ~ 0.69 μm) 和近红外波段 (0.76 ~ 0.89 μm)^[25-26]。本研究所用覆盖怀柔区的遥感影像数据共 4 景,其中全色数据 1 景,多光谱数据 3 景,4 景数据的获取时间均为 2009 年 10 月 22 日。

1.3 地面实测样地数据获取

地面实测样地数据分 2008 年 7 月~9 月、2009 年 7 月~9 月两期采集,选择远离林缘、人为干扰小、林相整齐的柞树纯林作为调查样地,人工布设 26 m × 26 m 的正方形样地 54 块。对样地的调查工作分为每木检尺和样地角点坐标记录两种:使用胸

径尺测量样地内每一单株木的胸径,使用手持激光测高仪测量立木树高;使用 GPS 记录样地 4 个角点的坐标^[1]。由于柞树为慢生树种,北京地区柞树蓄积量的连年生长量最大不超过 0.004 m³^[27],且蓄积是测量林木地表树干部分的材积,与枝叶无关,故地面实测样地数据获取时间与 ALOS 影像数据获取时间不一致所引起的误差可忽略。另本研究中所选的样地边长虽与影像分辨率不能构成整数倍关系,但在将地面样地转化为矢量图斑叠加在遥感影像上时,由于存在 GPS 测量误差、野外坡度修正等因素,样地边界几乎不可能与像元间的边界重合。对样地进行光谱值计算时,与样地边界相交的像元亦参与运算,本研究中样地边长与影像分辨率不成整数倍关系,会造成样地对应影像范围内像元的增加,但这种增加对每一样地都是一致的,对模型的拟合并不构成影响。

2 研究方法

2.1 实测样地蓄积量计算

实测确定林分蓄积的方法可分为标准木法和数表法。前者通过在样地内选择平均材积的树木作为标准木,伐倒并计算其精确材积从而实现样地蓄积的推算;后者则是通过查阅材积表,实现对样地蓄积的快速计算^[1]。本研究采用数表法计算样地内每一单株木的材积,累加获得每一实测样地的蓄积量,并将单位统一转换为 m³/hm²,作为蓄积量估测模型的因变量,数表法计算柞树材积的公式为^[28]

$$V = 0.0003D^2 + 0.0021D - 0.0231 \quad (1)$$

式中 V ——柞树单株木材积, m³

D ——柞树单株木胸径, m

2.2 ALOS 遥感数据预处理

首先,对 ALOS 数据做辐射定标和 FLAASH 大气校正,将影像的 DN 值转化为地表真实反射率值;再以北京 54 坐标系 3 度带的北京市 1:10 000 地形图参考,结合 30 m 分辨率 GDEM 数据(来源于中国科学院计算机网络信息中心国际科学数据镜像网站 <http://www.gscloud.cn>)对全色影像做正射校正;对正射校正后的全色影像做镶嵌处理,并以此作为多光谱影像正射校正的参考影像;正射校正处理过程中,每景影像控制点的选择均遵循均匀分布于整景影像且控制点总误差控制在 1 个像元内的原则,正射校正使用加拿大 PCI Geomatica 2012 软件的卫星轨道模型实现;最后,使用怀柔区矢量边界对执行前两步操作的数据进行裁剪,使用 Geomatica 2012 软件的 Pansharpen 模型,对裁剪后的研究区全色数据与多光谱数据做融合处理,最终生成研究区

2.5 m 分辨率融合数据(图 1)。

2.3 ALOS 遥感数据纹理分析

由于图像纹理形式的广泛性和多样性,至今学术界对其尚无公认的定义,纹理特征的提取方法也层出不穷^[29]。常见的纹理提取方法有:灰度共生矩阵(GLCM, Gray level co-occurrence matrix)法、马尔可夫随机场(MRF)法、小波变换法等^[29-30]。国内外学者的研究表明,基于灰度共生矩阵(GLCM)的纹理特征,在遥感影像的分类及反演中,取得了较高的精度^[12,18,20,22,31]。因此,本研究采用灰度共生矩阵法提取 ALOS 遥感数据的纹理特征。

2.3.1 基于灰度共生矩阵的纹理特征

Haralick 将纹理定义为:一种反映图像中同质现象的视觉特征,体现物体表面共有的内在属性,包含了物体表面结构组织排列的重要信息以及它们与周围环境的联系^[17,29,32]。灰度共生矩阵由 Haralick

于 1973 年提出,其原理为^[17]:

给定影像尺寸为 $M \times N$,灰度为 L ,GLCM 即为从影像中灰度为 i 的点 (k, l) 处的像元出发,统计与其距离为 $d = (m - k, n - l)$ 、灰度为 j 的点 (m, n) 处的像元,同时出现的概率 $P(i, j, d, \theta)$ 表示为

$$P(i, j, d, \theta) = \#\{(k, l), (m, n) \in (M \times N) | f(k, l) = i, f(m, n) = j\} \\ (i, j = 0, 1, 2, \dots, L - 1; m = 1, 2, 3, \dots, M; n = 1, 2, 3, \dots, N) \quad (2)$$

式中 d ——像素间相对距离,若 $d = 1$,表示相邻像素

θ ——像素间相对方向,一般考虑水平、对角线、垂直、反对角线 4 个方向(0° 、 45° 、 90° 、 135°)

基于灰度共生矩阵,Haralick 定义了 14 种纹理特征,其中,表 1 中的 8 种最为常用^[17]。

表 1 基于灰度共生矩阵的纹理特征及衍生指数

Tab.1 Texture parameters and derivative indices based on GLCM

基于灰度共生矩阵的 8 种纹理特征		基于纹理特征的 7 种衍生指数	
均值	$M_{me} = \frac{1}{L^2} \sum_{i,j=0}^{L-1} P_{i,j}$	$I_{hom-NDVI} = \frac{N_{nir-hom} - R_{hom}}{N_{nir-hom} + R_{hom}}$	
方差	$V_{var} = \sum_{i,j=0}^{L-1} P_{i,j} (i, j - \mu_{i,j})^2$	$I_{hom-DVI} = N_{nir-hom} - R_{hom}$	
同质性	$H_{hom} = \sum_{i,j=0}^{L-1} \frac{P_{i,j}}{1 + (i - j)^2}$	$I_{hom-RVI} = \frac{N_{nir-hom}}{R_{hom}}$	
对比度	$C_{con} = \sum_{i,j=0}^{L-1} P_{i,j} (i - j)^2$	$I_{hom-R1} = \frac{B_{hom}}{B_{hom} + G_{hom} + R_{hom} + N_{nir-hom}}$	
相异性	$D_{dis} = \sum_{i,j=0}^{L-1} P_{i,j} i - j $	$I_{hom-R2} = \frac{G_{hom}}{B_{hom} + G_{hom} + R_{hom} + N_{nir-hom}}$	
熵	$E_{ent} = \sum_{i,j=0}^{L-1} P_{i,j} (-\ln P_{i,j})$	$I_{hom-R3} = \frac{R_{hom}}{B_{hom} + G_{hom} + R_{hom} + N_{nir-hom}}$	
角二阶矩	$A_{ASM} = \sum_{i,j=0}^{L-1} (P_{i,j})^2$	$I_{hom-R4} = \frac{N_{nir-hom}}{B_{hom} + G_{hom} + R_{hom} + N_{nir-hom}}$	
相关性	$C_{cor} = \sum_{i,j=0}^{L-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{\sigma_i^2 \sigma_j^2}} \right]$		

纹理特征随着窗口大小、步长、方向 3 参数的改变而改变,其中,以对窗口大小发生改变影响反演精度的研究最为广泛^[11-13,20-23],但对于窗口大小影响反演精度规律性的探讨,尚无定论。本研究在固定纹理生成方向为 135° ,步长为 1 的前提下,分别采用 3×3 、 5×5 、 7×7 、 9×9 、 11×11 、 13×13 、 15×15 等 7 种窗口大小,分别对 ALOS 融合数据的 4 个波段生成前述 8 种纹理,试探索窗口大小影响反演精度的规律性。纹理的生成使用美国 Exelis 公司的 ENVI 5.0 遥感影像处理软件实现, 135° 的纹理生成方向与 1 的步长为其默认设置。

2.3.2 基于纹理特征的衍生指数

复杂的植被遥感,仅用个别波段或多个单波

段数据分析对比来提取植被信息是相当局限的,选用多光谱遥感数据的 2 个或多个波段进行混合运算,生成某些对植被长势、生物量等参数具有一定指示意义的数值,即为植被指数^[33]。植被指数在反演生物量、LAI、植被盖度等参数时,可有效减弱由林冠、土壤背景、光照角度等因素引起的变异^[11,34]。然而,研究表明, I_{RV} 、 I_{NDV} 、 I_{DV} 等植被指数在植被覆盖偏低或偏高时均出现不同程度的敏感性异常^[35],同时使用多个植被指数进行逐步回归时,则会出现自变量之间的共线性问题^[36],为提高对高郁闭度亚热带森林生物量的反演精度,Latifur 等提出利用各波段纹理特征的比值作为自变量进行多元逐步回归,得到了很高的反演精度^[11]。在

前人对纹理特征、植被指数的研究基础上,本研究将二者结合,提出基于纹理特征的衍生指数,即用各波段生成的纹理特征代替植被指数计算公式中的相应波段,试图探索7种基于纹理特征的衍生指数在蓄积量反演上的潜力,计算公式如表1所示(以同质性纹理特征为例说明,缩写为Hom,其余7种纹理特征相同)。

2.4 基于纹理及纹理指数的建模

在ArcGIS 10.2中,将地面实测样地坐标数据转化为面状矢量文件,与已生成的纹理特征和衍生指数波段叠加,提取每一波段上每一样地范围内的像元均值作为自变量,以每一样地的蓄积量作为因变量建立回归模型。54块柞树地面实测样地,随机选取36块用于建模,剩余18块用于模型精度的检验。本研究采用多元逐步回归模型,基于不同窗口的纹理特征、不同窗口纹理特征的衍

生指数、不同窗口纹理特征及衍生指数、所有窗口所有波段4个重复建立多元逐步回归模型。为避免模型自变量出现共线性问题,以容差(Tolerance)和方差膨胀因子(VIF)2个统计量为标准对模型进行筛选,判定准则为Tolerance大于0.1、VIF小于 $10^{[37-38]}$;为得到最优模型,以 R_{adj}^2 、RMSE、 p 值显著性3个统计量为标准对模型优劣进行检验和比较,从而得到最优模型;最后,对预留的18块柞树蓄积量精度检验样本,采用配对样本 t 检验法对最优模型进行精度检验。

3 结果与分析

3.1 基于不同窗口纹理特征的蓄积量回归模型

基于7种不同窗口生成的8种纹理特征分别与柞树蓄积量进行多元逐步回归的试验结果(表2)表明:ALOS融合数据的4个波段生成的纹理特征与

表2 基于不同窗口纹理特征的蓄积量回归模型表

Tab.2 Stand volume regression models obtained from texture parameters under different window sizes

窗口大小	模型拟合统计量			模型参数		
	R_{adj}^2	RMSE/($m^3 \cdot hm^{-2}$)	p 值显著性	常量和自变量	回归系数	p 值显著性
3×3	0.148	29.1479	0.012	常量	2.194	0.028
				$N_{nir-ASM}$	4.265	0.012
5×5	0.183	28.5473	0.005	常量	2.520	0.002
				$N_{nir-ASM}$	4.308	0.005
7×7	0.205	28.1568	0.003	常量	2.628	0.001
				$N_{nir-ASM}$	4.487	0.003
9×9	0.215	27.9719	0.003	常量	2.708	0.000
				$N_{nir-ASM}$	4.620	0.003
11×11	0.217	27.9438	0.002	常量	2.780	0.000
				$N_{nir-ASM}$	4.699	0.002
13×13	0.215	27.9719	0.003	常量	2.836	0.000
				$N_{nir-ASM}$	4.773	0.003
15×15	0.212	28.0325	0.003	常量	2.878	0.000
				$N_{nir-ASM}$	4.850	0.003

柞树蓄积量相关性较低,4个波段生成的纹理特征与柞树蓄积量的最大 R_{adj}^2 出现在 11×11 窗口($R_{adj}^2 = 0.217$, RMSE为 $27.9438 m^3/hm^2$);在对每一窗口的柞树蓄积量模型拟合过程中,4个波段的均值(M_{me})、方差(V_{var})、同质性(H_{hom})等8种纹理特征,均仅有近红外波段(N_{nir})的角二阶矩(A_{ASM})纹理特征进入了回归模型,表明 $N_{nir-ASM}$ 与柞树蓄积量具有较强的相关性,其原因可能为:森林植被在近红外波段具有敏感响应,国内外多位学者的研究均得出过相同或相似的结论^[11,35,39]。 A_{ASM} 是反映图像灰度分布和纹理粗细度的纹理特征, A_{ASM} 值大表明一种较均一和规则变化的纹理模式^[40],森林植被的林冠常呈现出较规则的纹理,使其在 A_{ASM} 纹理特

征比其它纹理特征具有更大的取值,从而增强了对森林冠层的响应,这与Jensen将 A_{ASM} 引入分类研究,提高了城乡交错带分类精度的试验结果相吻合^[41]。基于4个波段纹理特征的蓄积量模型 R_{adj}^2 随着窗口的增大呈抛物线变化趋势,在 11×11 窗口达到峰值,但由于各个模型的 R_{adj}^2 在7个窗口间的变化幅度较微弱,这种变化趋势并不明显(图2)。

3.2 基于不同窗口衍生指数的蓄积量回归模型

相比于基于纹理特征的模型,基于不同纹理特征的7种衍生指数波段蓄积量回归模型,在拟合优度上有了明显的提高(表3),并在 11×11 窗口下, R_{adj}^2 为最大值($R_{adj}^2 = 0.603$, RMSE为 $19.8994 m^3/hm^2$),表明基于纹理特征引入植被指数的计算方法,生成

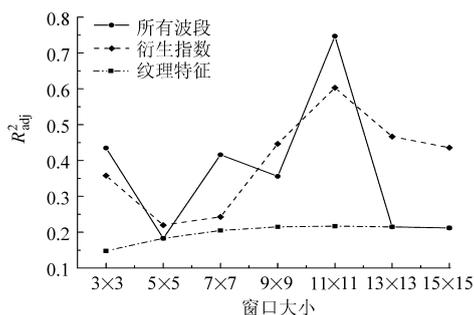


图 2 基于不同窗口的蓄积量模型 R^2_{adj} 变化曲线

Fig. 2 Adjusted coefficients of determination (R^2_{adj}) for the relationships between stand volume and texture parameters obtained at different window sizes

新的衍生波段能够显著地提升柞树蓄积量回归模型的拟合优度,其原因可能是新生成的衍生指数,结合了纹理特征与植被指数的优点,增大了像元的有用

信息,抑制了噪声。基于角二阶矩的衍生指数 $R4 (I_{ASM-R4}$,计算方法参考表 1),分别在 9、11、13、15 窗口的多元逐步回归模型中成为第 1 个进入模型的自变量,说明相比于其它衍生指数波段, I_{ASM-R4} 与柞树蓄积量具有更高的相关性。基于不同窗口衍生指数回归模型的 R^2_{adj} ,随着窗口的增大呈现减小-增至最大-减小的变化趋势(图 2),在 11×11 窗口下增至最大($R^2_{adj} = 0.603$),说明纹理生成窗口的变化对基于纹理衍生指数的柞树蓄积量反演模型有明显的影 响, 11×11 的纹理生成窗口可能是基于 ALOS 融合数据柞树蓄积量反演的最佳窗口。

3.3 基于不同窗口所有波段的蓄积量回归模型

将每一窗口下的纹理特征与衍生指数波段相结合进行柞树蓄积量多元回归,结果表明:在 3、7、11 窗口下, R^2_{adj} 再次得到明显提高,并在 11×11 窗口下达到

表 3 基于不同窗口衍生指数的蓄积量回归模型表

Tab. 3 Stand volume regression models obtained from derivative indices under different window sizes

窗口大小	模型拟合统计量			模型参数			自变量共线性诊断			
	R^2_{adj}	RMSE/($m^3 \cdot hm^{-2}$)	p 值显著性	自变量和常量	回归系数	p 值显著性	容差	方差膨胀因子		
3 × 3	0.358	25.3018	0.001	常量	4.520	0.000	0.992	1.008		
				I_{ent-R1}	1.211	0.006				
				I_{me-R1}	-17.857	0.007			0.991	1.009
				I_{cor-R3}	1.417	0.044			0.990	1.010
5 × 5	0.220	27.8964	0.006	常量	11.893	0.000	0.913	1.095		
				I_{me-R2}	-40.782	0.003				
				$I_{ASM-NDVI}$	4.278	0.046			0.913	1.095
7 × 7	0.243	27.4808	0.004	常量	12.133	0.000	0.911	1.098		
				I_{me-R2}	-41.614	0.002				
				$I_{ASM-NDVI}$	4.425	0.022			0.911	1.098
9 × 9	0.447	23.4880	0.000	常量	23.407	0.023	0.214	4.681		
				I_{ASM-R4}	43.907	0.001			0.960	1.042
				I_{dis-R2}	-3.088	0.004			0.523	1.911
				I_{me-R1}	-26.753	0.002			0.185	5.399
				I_{hom-R4}	-106.558	0.037				
11 × 11	0.603	19.8994	0.000	常量	1.090	0.203	0.939	1.065		
				I_{ASM-R4}	22.018	0.000			0.742	1.348
				I_{var-R2}	-2.848	0.013			0.896	1.115
				$I_{ent-RV1}$	0.511	0.000			0.671	1.490
				I_{ent-R2}	-9.630	0.001			0.871	1.148
				$I_{con-NDVI}$	2.087	0.020				
13 × 13	0.467	23.0503	0.000	常量	6.429	0.002	0.927	1.079		
				I_{ASM-R4}	13.554	0.022			0.649	1.541
				I_{ent-R2}	-15.329	0.000			0.598	1.671
				$I_{var-RV1}$	0.371	0.001			0.825	1.212
				$I_{me-NDVI}$	-8.250	0.041				
15 × 15	0.436	23.7189	0.000	常量	-1.262	0.677	0.690	1.450		
				I_{ASM-R4}	6.184	0.368			0.775	1.290
				I_{ent-R2}	-9.718	0.003			0.590	1.696
				$I_{cor-RV1}$	-0.242	0.003			0.843	1.186
				I_{me-R3}	25.640	0.045				

最大值 $R_{adj}^2 = 0.747$ (RMSE 为 $15.8876 \text{ m}^3/\text{hm}^2$), 该值也是基于不同窗口的 3 组柞树蓄积量估测模型拟合实验中 R_{adj}^2 的最大值(表 4、图 2)。本组实验中, 柞树蓄积量估测模型 R_{adj}^2 的最大值再次出现在 11×11 窗口, 说明 11×11 的纹理生成窗口是基于 ALOS 融合数据进行柞树蓄积量反演的最佳窗口。其原因可能是: ALOS 融合数据的分辨率为 2.5 m , 11×11 的窗口所对应的面积为 756.25 m^2 , 这与实测样地面积 676 m^2 最为接近, 即: 样地范围内每一由 GLCM 新生成的像元 DN 值, 均由原始波段上与样地面积近似的, 样地内或周边 11×11 窗口面积范围内的像元值计算而来; 在规避远离林缘和人为干扰的前提下, 外业样地的布设在整个林分中是随机且具代表性的, 这与样地范围内的纹理像元是由样地范围内及周边的原始波段像元所生成的相对应; 这种取值及取值范围的近似对应性, 使得样地内新生成的纹理特征值在代表固定面积样地内的森林参数时误差最小。若窗口小于 11×11 , 窗口对应的影像面积小于样地对应的影像面积, 则样地范围内由窗口生成

的纹理像元 DN 值的统计值, 并不能完全代表样地面积内森林参数的特征值; 若窗口大于 11×11 , 窗口对应的影像面积大于样地对应的影像面积, 则样地范围内由窗口生成的纹理像元, 包含了样地面积以外的植被信息, 亦使得样地内的纹理像元 DN 值与实测样地范围内的森林参数特征值产生误差, 从而导致纹理特征与蓄积量相关性的降低。在 3×3 窗口下, 回归模型呈现较高的 R_{adj}^2 , 其原因可能是: 3×3 窗口下生成的样地范围内的纹理像元, 虽仅能代表很小面积上的森林特征, 但这些纹理像元几乎全是由样地范围内的原始波段像元以 3×3 窗口为单位计算得出(与样地边界相交的一圈纹理像元除外, 这些纹理像元在生成时引入了与其相邻的一圈样地外的像元); 3×3 窗口内所含森林信息虽少, 但几乎所有纹理像元都反映了样地内的森林特征(其余窗口下, 样地内纹理像元的生成均不同程度的引入样地范围外的原始波段像元), 因此, 基于 3×3 窗口的回归模型获得了较高的 R_{adj}^2 , 这一结果与周靖靖、Colombo 等的试验结果相似^[42-43]。

表 4 基于不同窗口所有波段的蓄积量回归模型表

Tab. 4 Stand volume regression models obtained from all bands under different window sizes

窗口大小	模型拟合统计量			模型参数			自变量共线性诊断	
	R_{adj}^2	RMSE/($\text{m}^3 \cdot \text{hm}^{-2}$)	p 值显著性	自变量和常量	回归系数	p 值显著性	容差	方差膨胀因子
3×3	0.435	23.7337	0.000	常量	4.338	0.000	0.991	1.009
				I_{ent-R1}	1.181	0.005		
				I_{mea-R1}	-23.701	0.001		
				$B_{blue-dis}$	1.747	0.027		
				I_{cor-R3}	1.439	0.030		
5×5	0.183	28.5473	0.005	常量	2.520	0.002	0.966	1.035
				$N_{nir-ASM}$	4.308	0.005		
				$N_{nir-ASM}$	5.325	0.000		
7×7	0.416	24.1317	0.000	I_{con-R2}	-0.828	0.004	0.971	1.030
				$I_{var-NDVI}$	-0.267	0.031		
				常量	2.637	0.000		
				$N_{nir-ASM}$	5.284	0.000		
9×9	0.356	25.3491	0.000	I_{var-R2}	-0.824	0.007	0.969	1.032
				常量	2.127	0.019		
				$N_{nir-ASM}$	8.041	0.000		
				I_{var-R2}	-4.258	0.000		
				$I_{ent-RV1}$	0.554	0.000		
11×11	0.747	15.8876	0.000	$N_{nir-dis}$	1.736	0.001	0.651	1.536
				$I_{dis-NDVI}$	4.398	0.000		
				I_{ASM-R3}	-12.996	0.003		
				常量	2.836	0.000		
				$N_{nir-ASM}$	4.773	0.003		
13×13	0.215	27.9719	0.003	常量	2.878	0.000	0.349	2.863
				$N_{nir-ASM}$	4.850	0.003		
15×15	0.212	28.0325	0.003	常量	2.878	0.000		
				$N_{nir-ASM}$	4.850	0.003		

3.4 基于所有窗口所有波段的蓄积量回归模型

将所有窗口下生成的纹理特征及衍生波段都作为自变量,对柞树蓄积量进行多元逐步回归,得到最大的 R^2_{adj} ($R^2_{adj} = 0.807$, RMSE 为 $13.8565 \text{ m}^3/\text{hm}^2$), 如表 5 所示。比基于不同窗口纹理特征的蓄积量回归模型 ($R^2_{adj} = 0.217$, RMSE 为 $27.9438 \text{ m}^3/\text{hm}^2$)、不同窗口衍生指数的蓄积量回归模型 ($R^2_{adj} =$

0.603 , RMSE 为 $19.8994 \text{ m}^3/\text{hm}^2$) 以及不同窗口所有波段的蓄积量回归模型 ($R^2_{adj} = 0.747$, RMSE 为 $15.8876 \text{ m}^3/\text{hm}^2$), 在拟合优度上均有显著的提升。柞树蓄积量模型预测值与样地观测值散点图亦呈现出良好的拟合效果(图 3), 这一实验结果与 Latifur^[11]的研究结果相吻合。

表 5 基于所有窗口所有波段的蓄积量回归模型表

Tab. 5 Stand volume regression models obtained from all bands under all window sizes

模型拟合统计量			模型参数			自变量共线性诊断	
R^2_{adj}	RMSE/($\text{m}^3 \cdot \text{hm}^{-2}$)	p 值显著性	自变量和常量	回归系数	p 值显著性	容差	方差膨胀因子
0.807	13.8565	0.000	常量	-3.081	0.016		
			11 窗口 $N_{nir-ASM}$	8.726	0.000	0.411	2.436
			11 窗口 I_{var-R2}	-4.625	0.000	0.875	1.143
			11 窗口 $I_{ent-RV1}$	0.576	0.000	0.941	1.063
			3 窗口 I_{ent-R1}	0.050	0.921	0.204	4.897
			3 窗口 $N_{nir-dis}$	2.592	0.000	0.504	1.986
			15 窗口 I_{con-R4}	5.329	0.002	0.574	1.742
			13 窗口 $I_{ent-NDVI}$	1.266	0.019	0.212	4.719

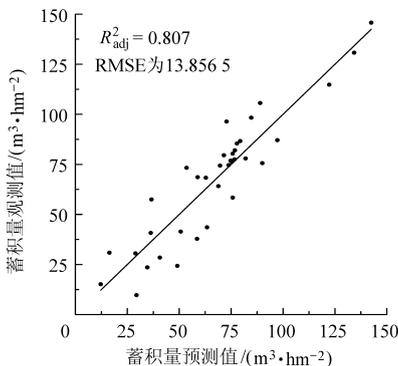


图 3 基于所有窗口所有波段蓄积量模型实测值与观测值
Fig. 3 Relationship between observed and model predicted
Xylosma racemosum stand volume using all bands
under all window sizes

3.5 模型精度验证

选取最优柞树蓄积量估测模型(表 5), 计算 18 块预留柞树样地的蓄积量遥感模型估测值, 模型拟合效果如图 4 所示, 经配对样本 t 检验结果显示: 柞树蓄积量模型预测均值为 $75.9067 \text{ m}^3/\text{hm}^2$, 实测均值为 $73.9478 \text{ m}^3/\text{hm}^2$, 绝对误差为 $1.9589 \text{ m}^3/\text{hm}^2$, RMSE 为 $18.4930 \text{ m}^3/\text{hm}^2$, 成对样本检验 p 值显著性 ($p = 0.822$) 远大于 0.05, 即可认为柞树蓄积量模型预测值与观测值没有显著性差异, 模型预测结果较理想。

4 讨论

可见光遥感的传感器空间分辨率越来越朝着精细化的方向发展, 然而, 这种空间分辨率的提高并没

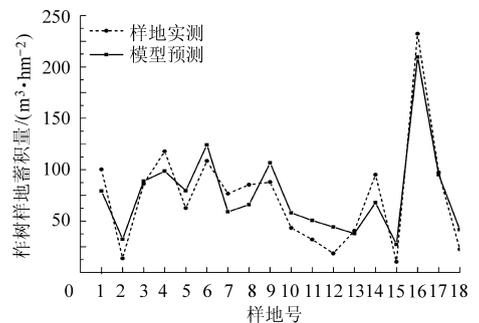


图 4 柞树蓄积量模型预测值与实测值散点图
Fig. 4 Scatter plots of *Xylosma racemosum* stand volume
between model predicted value and observed value

有对影像的光谱信息产生质的影响, 却使得影像上地物的结构、形状、纹理等特征信息得到极大的丰富。较之光谱信息, 高空间分辨率遥感影像的纹理信息对森林植被的描述更为准确^[44]。这是因为: 光学传感器在进行森林植被成像时, 主要捕获了森林的冠层信息及相关冠层阴影, 阴影光谱的混入, 影响了森林冠层的光谱特征^[45], 笔者也曾尝试使用原始光谱数据、植被指数进行蓄积量的多元逐步回归建模, 但结果显示没有变量进入到多元逐步回归模型中, 即无法得出模型。

纹理特征能够有效地减少阴影的影响, 增大森林冠层与灌草的差别, 突出目标地物的信息, 使其与森林参数的回归模型相关性增加^[44, 46]。在反演森林参数时, 较之高空间分辨率影像的光谱特征, 纹理特征存在巨大的潜力^[11-13, 15], 这在本研究中得以证实。波段比值或植被指数, 可有效减弱由林冠、土壤

背景、光照角度等因素引起的变异^[11,31],然而,光谱数据的饱和性问题,使仅以光谱比值或植被指数反演森林参数,精度提升乏力。Latifur 将纹理特征与比值波段相结合反演亚热带森林生物量的实验,对基于纹理的比值波段是否能够综合纹理特征及比值波段的优点提升反演精度做了探索,得到了高精度的森林生物量反演模型,证实了这种结合确实能够兼顾二者的优点^[11,47]。本研究在此基础上,探索了纹理特征与植被指数相结合是否能够提升柞树蓄积量反演精度的问题,结果表明:基于纹理特征的衍生指数,确实能够将纹理特征反映丰富地物纹理结构、植被指数与森林植被有良好相关性的优点结合起来,得到了高精度的拟合模型,这与 Latifur 及 Janet 的研究结果相吻合^[11,47]。

本研究探讨了 ALOS 卫星 2.5 m 分辨率融合数据纹理特征及衍生纹理指数反演柞树蓄积量最佳纹理生成窗口及最优拟合模型的问题。对使用高分辨率遥感数据纹理特征反演森林参数纹理窗口的选择、纹理特征的处理具有一定的参考价值和指导意义。由于高分辨率遥感数据纹理特征的生成需要耗费较长的处理时间,且最佳纹理特征的选择也需要多次重复试验(窗口大小、步长、方向)生成大量中间数据才能得出,这些都对计算机硬件的性能提出较高的要求,使得目前国外学者对影像纹理特征的研究也多限于窗口大小的探讨,方向性及步长相关

的研究则鲜有报道,纹理特征生成的这两个因素在提高森林参数反演精度上是否依然蕴含着巨大潜力,尚不可知。随着计算机硬件设备的发展,针对高分辨率遥感数据纹理特征生成方向及步长的探索,将会成为下一阶段的研究重点。

5 结 论

(1) 使用 ALOS 卫星 2.5 m 分辨率融合数据的纹理特征及衍生纹理指数能够对柞树蓄积量进行较精确的估测。

(2) 生成纹理的窗口大小对柞树蓄积量估测模型有显著的影响,基于不同窗口的纹理信息建立的蓄积量估测模型, R_{adj}^2 差异较大;ALOS 卫星 2.5 m 分辨率融合数据的最优单窗口柞树蓄积量估测模型出现在 11×11 窗口, $R_{adj}^2 = 0.747$;地面实测样地面积与纹理生成窗口的大小最接近时,柞树蓄积量反演模型的精度最高。

(3) 同一纹理生成窗口下的柞树蓄积量建模,基于纹理特征的衍生纹理指数模型比基于波段纹理特征的模型,在拟合优度上具有显著提升;结合纹理特征及衍生纹理指数建立柞树蓄积量回归模型,模型拟合优度可再次得到有效提升;利用不同窗口下的纹理特征及衍生纹理指数,可进行柞树蓄积量多元逐步回归建模,且能够得到最优的柞树蓄积量估测模型($R_{adj}^2 = 0.807$, RMSE 为 $13.8565 \text{ m}^3/\text{hm}^2$)。

参 考 文 献

- 1 孟宪宇. 测树学[M]. 北京:中国林业出版社,1996:58,128
- 2 刘志华,常禹,陈宏伟. 基于遥感、地理信息系统和人工神经网络的呼中林区森林蓄积量估测[J]. 应用生态学报,2008, 19(9):1891-1896.
Liu Zhihua, Chang Yu, Chen Hongwei. Estimation of forest volume in Huzhong forest area based on RS, GIS and ANN[J]. Chinese Journal of Applied Ecology, 2008, 19(9):1891-1896. (in Chinese)
- 3 赵宪文. 林业遥感定量估测[M]. 北京:中国林业出版社,1997:24-40.
- 4 李崇贵,赵宪文,李春干. 森林蓄积量遥感估测理论与实现[M]. 北京:科学出版社,2006:1.
- 5 刘峰,谭畅,张贵,等. 长白落叶松单木参数与生物量车载 LiDAR 估测[J]. 农业机械学报,2013, 44(9):219-224.
Liu Feng, Tan Chang, Zhang Gui, et al. Estimation of forest parameter and biomass for individual pine trees using airborne LiDAR [J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(9):219-224. (in Chinese)
- 6 何亚娟,潘学标,裴志远,等. 基于 SPOT 遥感数据的甘蔗叶面积指数反演和产量估算[J]. 农业机械学报. 2013, 44(5): 226-231.
He Yajuan, Pan Xuebiao, Pei Zhiyuan, et al. Estimation of LAI and yield of sugarcane based on SPOT remote sensing data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(5):226-231. (in Chinese)
- 7 刘庭威,曾明宇,旦增. 基于 ALOS 数据的巨尾桉蓄积量遥感估测——以广西平南县为例[J]. 中南林业调查规划,2011, 30(4):53-55.
- 8 杨永恬. 基于多源遥感数据的森林蓄积量估测方法研究[D]. 北京:中国林业科学研究院,2010.
Yang Yongtian. Study on estimating methods of forest stem volume base on multi-source remote sensing image[D]. Beijing: Chinese Academy of Forestry, 2010. (in Chinese)
- 9 杨长青. 基于 SPOT-5 的川西南山地常绿阔叶林叶面积指数及蓄积量估测研究[D]. 雅安:四川农业大学,2012.
Yang Changqing. Estimation of leaf area index and volume of montane evergreen broad-leaved forest based on the SPOT-5 image of mountainous area in Southwest Sichuan[D]. Ya'an: Sichuan Agricultural University, 2012. (in Chinese)
- 10 王轶夫. 基于人工神经网络的天然林生物量遥感估测[D]. 北京:北京林业大学,2013.
Wang Yifu. The study of forest biomass estimation model based on neural network[D]. Beijing: Beijing Forestry University,

2013. (in Chinese)
- 11 Latifur R S, Janet E N. Improved forest biomass estimates using ALOS AVNIR-2 texture indices [J]. *Remote Sensing of Environment*, 2011, 115(4):968-977.
- 12 Kayitakire F, Hamel C, Defourny P. Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery [J]. *Remote Sensing of Environment*, 2006, 102(3-4):390-401.
- 13 Wolter P, Philip A T, Brian R S. Estimation of forest structural parameters using 5 and 10 meter SPOT-5 satellite data [J]. *Remote Sensing of Environment*, 2009, 113(9):2019-2036.
- 14 Spanner M A, Pierce L L, Peterson D L, et al. Remote sensing of temperate coniferous leaf area index: the influence of canopy closure, understory vegetation, and background reflectance [J]. *International Journal of Remote Sensing*, 1990, 11(1):95-111.
- 15 Franklin S E, Peddle D R. Spectral texture for improved class discrimination in complex terrain [J]. *International Journal of Remote Sensing*, 1989, 10(8):1437-1443.
- 16 Marceau D J, Howarth P J, Dubois J M, et al. Evaluation of the grey-level co-occurrence matrix method for land cover classification using SPOT imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1990, 28(4):513-519.
- 17 Haralick R, Shanmugan K, Dinstein I. Textural features for image classification [C]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1973, 3(6):610-621.
- 18 Kuplich T M, Curran P J, Atkinson P M. Relating SAR image texture to the biomass of regenerating tropical forest [J]. *International Journal of Remote Sensing*, 2005, 26(21):4829-4854.
- 19 Luckman A, Frery A C, Yanasse C C F, et al. Texture in airborne SAR imagery of tropical forest and its relationship to forest regeneration stage [J]. *International Journal of Remote Sensing*, 1997, 18(6):1333-1349.
- 20 胡玉福,邓良基,匡先辉,等. 基于纹理特征的高分辨率遥感图像土地利用分类研究 [J]. *地理与地理信息科学*, 2011, 27(5):42-45.
- Hu Yufu, Deng Liangji, Kuang Xianhui, et al. Study on land use classification of high resolution remote sensing image based on texture feature [J]. *Geography and Geo-Information Science*, 2011, 27(5):42-45. (in Chinese)
- 21 李利红,张华国,厉冬玲,等. 基于多尺度纹理和光谱信息的海岛土地利用遥感分类方法研究 [J]. *海洋学研究*, 2013, 31(2):35-44.
- Li Lihong, Zhang Huaguo, Li Dongling, et al. Study on island land use classification method based on multi-scale texture and spectral information [J]. *Journal of Marine Science*, 2013, 31(2):35-44. (in Chinese)
- 22 金飞. 基于纹理特征的遥感影像居民地提取技术研究 [D]. 郑州:解放军信息工程大学, 2013.
- 23 陈敏. 基于纹理特征的遥感图像分类技术研究 [D]. 福州:福州大学, 2004.
- 24 李玲,王红,刘庆生,等. 基于纹理特征和支持向量机的 ALOS 图像土地覆被分类 [J]. *国土资源遥感*, 2011(4):58-63.
- Li Ling, Wang Hong, Liu Qingsheng, et al. Land cover classification using ALOS image based on textural features and support vector machine [J]. *Remote Sensing for Land & Resources*, 2011(4):58-63. (in Chinese)
- 25 严恩萍,林辉,莫登奎,等. 基于 ALOS 数据的遥感植被分类研究 [J]. *中南林业科技大学学报:自然科学版*, 2010, 30(11):37-42.
- Yan Enping, Lin Hui, Mo Dengkui, et al. Vegetation classification based on ALOS data [J]. *Journal of Central South University of Forestry & Technology*, 2010, 30(11):37-42. (in Chinese)
- 26 严恩萍. 中高分辨率遥感影像阔叶林信息提取研究 [D]. 长沙:中南林业科技大学, 2011.
- 27 张红梅,王新杰,闫金华,等. 北京市栎类植物空间分布及生长过程分析 [J]. *北京林业大学学报*, 2010, 32(增刊1):71-79.
- Zhang Hongmei, Wang Xinjie, Yan Jinhua, et al. Analysis on spatial distribution and growth process of oak forests in Beijing [J]. *Journal of Beijing Forestry University*, 2010, 32(Supp.1):71-79. (in Chinese)
- 28 许景伟,王长宪,李琪,等. 立木、木材材积速查手册 [M]. 济南:山东科学技术出版社, 2008.
- 29 刘丽,匡纲要. 图像纹理特征提取方法综述 [J]. *中国图象图形学报*, 2009, 14(4):622-635.
- Liu Li, Kuang Gangyao. Overview of image textural feature extraction methods [J]. *Journal of Image and Graphics*, 2009, 14(4):622-635. (in Chinese)
- 30 曹晶晶,王一鸣,毛文华,等. 基于纹理和位置特征的麦田杂草识别方法 [J]. *农业机械学报*, 2007, 38(4):107-110.
- Cao Jingjing, Wang Yiming, Mao Wenhua, et al. Weed detection method in wheat field based on texture and position features [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2007, 38(4):107-110. (in Chinese)
- 31 Wood E M, Pidgeon A M, Radeloff V C, et al. Image texture as a remotely sensed measure of vegetation structure [J]. *Remote Sensing of Environment*, 2012, 121:516-526.
- 32 Haralick R M. Statistical and structural approaches to texture [J]. *Proceedings of the IEEE*, 1979, 67(5):786-804.
- 33 Mather P M. *Computer processing of remotely sensed images* [M]. 2nd ed. Chichester: Wiley, 1999: 100-120.
- 34 Elvidge C D, Chen Z. Comparison of broad-band and narrow band red and near infrared vegetation indices [J]. *Remote Sensing of Environment*, 1995, 54(1):38-48.
- 35 赵英时. 遥感应用分析原理与方法 [M]. 北京:科学出版社, 2003:375-383.
- 36 Foody G M, Cutler M E, McMorow J, et al. Mapping the biomass of Bornean tropical rain forest from remotely sensed data [J]. *Global Ecology and Biogeography*, 2001, 10(4):379-387.
- 37 Belsley D A. *Conditioning diagnostics* [M]. John Willy & Sons, 1990.

- 38 Douglas C M, Peck E A, & Vining G G. Introduction to linear regression analysis[M]. 4th ed. New Jersey: Wiley & Sons Publication, 2006:323 – 368.
- 39 Thenkabail P S, Stucky N, Griscom B W, et al. Biomass estimations and carbon stock calculations in the oil palm plantations of African derived savannas using IKONOS data[J]. International Journal of Remote Sensing, 2004,25(23):5447 – 5472.
- 40 韦玉春,汤国安,杨昕,等. 遥感数字图像处理教程[M]. 北京:科学出版社,2007:52 – 57.
- 41 Jensen J R, Toll D L. Detecting residential land-use developments at urban fringe[J]. Photogrammetric Engineering & Remote Sensing, 1982,48(4):629 – 643.
- 42 Zhou J J, Zhao Z, Zhao Q X, et al. Quantification of aboveground forest biomass using Quickbird imagery, topographic variables and field data[J]. Journal of Applied Remote Sensing, 2013,7:073484 – 1 – 18.
- 43 Colombo R, Bellingeri D, Fasolini D, et al. Retrieval of leaf area index in different vegetation types using high resolution satellite data[J]. Remote Sensing of Environment, 2003,86(1):120 – 131.
- 44 刘龙飞,陈云浩,李京. 遥感影像纹理分析方法综述与展望[J]. 遥感技术与应用, 2003, 18(6):441 – 446.
Liu Longfei, Chen Yunhao, Li Jing. Texture analysis methods used in remote sensing images[J]. Remote Sensing Technology and Application, 2003, 18(6):441 – 446. (in Chinese)
- 45 Toll D L. An evaluation of simulated Thematic mapper data and Landsat MSS data for discriminating suburban and regional land use and land cover[J]. Photogrammetric Engineering and Remote Sensing, 1984, 50(12):1713 – 1724.
- 46 王昆,张晓丽,王珊,等. 鹭峰地区 QuickBird 影像纹理特征与生物量估测关系初探[J]. 地理与地理信息科学,2013, 29(3):52 – 55.
Wang Kun, Zhang Xiaoli, Wang Shan, et al. Study on the relationship between texture of Quickbird image and biomass estimation in area of Jiufeng[J]. Geography and Geo-Information Science, 2013, 29(3):52 – 55. (in Chinese)
- 47 Janet E N, Latifur R S. Improved biomass estimation using the texture parameters of two high-resolution optical sensors[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(3):930 – 948.

Estimating Stand Volume of *Xylosma racemosum* Forest Based on Texture Parameters and Derivative Texture Indices of ALOS Imagery

Liu Jun¹ Bi Huaxing¹ Zhu Peilin² Sun Jing³ Zhu Jinzhao¹ Chen Tao⁴

(1. College of Soil and Water Conservation, Beijing Forestry University, Beijing 100083, China

2. College of Forestry, Beijing Forestry University, Beijing 100083, China

3. Department of Urban Planning and Environment, KTH Royal Institute of Technology, Stockholm 10044, Sweden

4. National Marine Consulting Center, State Oceanic Administration, Beijing 100860, China)

Abstract: The *Xylosma racemosum* forest located in Huairou District of Beijing was chosen as research objects, texture parameters as well as derivative texture indices of different window sizes from ALOS fusion imagery with resolution of 2.5 m were measured. Stepwise multiple regression models were developed to describe the relationship between textures (including texture parameters and derivative texture indices) and field measurements of stand volume. The main objective was to compare estimation accuracy between model established by texture parameters and that by derivative texture indices, select the most effective *Xylosma racemosum* stand volume estimate model and select the most effective window size. Results indicate that the value of adjusted R^2 of fitting models established by derivative texture indices were better than those of texture parameters at the same window size, the value of adjusted R^2 of stand volume model could be improved significantly by combination of texture parameters and derivative texture indices at the same window size, the optimal estimation model of *Xylosma racemosum* stand volume was obtained when all of the texture parameters and derivative texture indices of all window sizes were introduced into stepwise multiple regression, 11×11 was the optimal window size with the largest adjusted R^2 for fitting *Xylosma racemosum* stand volume by texture parameters and derivative texture indices generated at one single window size.

Key words: *Xylosma racemosum* Stand volume Remote sensing Texture parameters Derivative texture indices